

Prediction of Financial Distress Based on the Theory of Rough Sets Compared to Artificial Neural Networks¹

Seyed Amirmohamad Hejaziyan², Gholamreza Mansourfar³,
Farzad Ghayour⁴

Received: 2023/12/28

Accepted: 2024/05/30

Research Paper

Abstract

In the era when companies are facing many challenges to survive in competitive markets, it is important to identify the factors affecting financial crises. One of the ways to help investors and companies is to provide models to predict financial distress. The purpose of this research is to investigate the ability of rough set theory and compare it with artificial and fuzzy neural networks to predict the financial distress of companies active in the Tehran Stock Exchange. For this purpose, 329 distressed companies from non-distressed corporations were selected during the period of 2006 to 2020. The neural networks investigated in this research are: Multi-layer Perceptron (MLP) neural network, Radial Basis Function (RBF) network, and Adaptive Fuzzy Inference Network (ANFIS) as well as the software used to create the ROSETTA rough set and the software the tool used to design artificial and fuzzy neural networks is MATLAB software. The results obtained in this research show the high efficiency of the rough sets model with 98/7 percent accuracy for predicting financial distress.

Key Words: Financial Distress, Rough Set Theory, Artificial neural network, Predicting


JEL Classification: C02, B26, C45, G17, G33.

1. doi: 10.22034/JSE.2023.12135.2083

2. M.Sc. Department of Financial Management, Urmia University, Urmia, Iran. (ahejaziyan@yahoo.com).

3. Associate Professor, Department of Accounting, Urmia University, Urmia, Iran. (Corresponding Author). (g.mansourfar@urmia.ac.ir).

4. Assistant Professor, Department of Accounting, Urmia University, Urmia, Iran. (f.ghayour@urmia.ac.ir).





سازمان بورس و اوراق بهادار، مرکز پژوهش، توسعه و مطالعات اسلامی

فصلنامه بورس اوراق بهادار، سال هفدهم، شماره ۶۶، تابستان ۱۴۰۳، صص ۱۴۰-۱۱۵

پیش‌بینی درماندگی مالی بر مبنای تئوری مجموعه‌های راف در مقایسه با شبکه‌های عصبی مصنوعی^۱

سیدامیرمحمد حجازیان^۲، غلامرضا منصورفر^۳، فرزاد غیور^۴

تاریخ دریافت: ۱۴۰۲/۱۰/۰۷

تاریخ پذیرش: ۱۴۰۳/۰۳/۰۹

مقاله پژوهشی

چکیده

در عصری که شرکت‌ها برای بقا در بازارهای رقابتی با چالش‌های فراوانی روبه‌رو هستند، شناسایی عوامل تاثیرگذار بر بحران‌های مالی اهمیت می‌یابد. یکی از راه‌های کمک به سرمایه‌گذاران و شرکت‌ها ارائه الگوهایی برای پیش‌بینی درماندگی مالی است. هدف این پژوهش، بررسی توانایی تئوری مجموعه راف و مقایسه آن با شبکه‌های عصبی مصنوعی و فازی برای پیش‌بینی درماندگی مالی شرکت‌های فعال در بورس اوراق بهادار تهران است. بدین منظور ۳۲۹ جفت شرکت سالم و درمانده مالی در بازه زمانی سال‌های ۱۳۸۵-۱۳۹۹ انتخاب شده‌است. شبکه‌های عصبی بررسی شده در این پژوهش عبارتند از: شبکه عصبی پرسپترون چندلایه (MLP) و شبکه عملکرد پایه شعاعی (RBF) و شبکه استنتاج فازی انطباق‌پذیر (ANFIS) و همچنین نرم‌افزار مورد استفاده برای ایجاد تئوری مجموعه راف ROSETTA و نرم‌افزار مورد استفاده به منظور طراحی شبکه‌های عصبی مصنوعی و فازی نرم افزار MATLAB است. نتایج به دست آمده در این پژوهش نشان از کارایی بالای مدل مجموعه‌های راف با دقت ۹۸/۷ درصد به منظور پیش‌بینی درماندگی مالی دارد.

واژه‌های کلیدی: درماندگی مالی، تئوری مجموعه راف، پیش‌بینی، شبکه عصبی مصنوعی.

طبقه‌بندی موضوعی: B26, C45, G17, G33, C02

doi: 10.22034/JSE.2023.12135.2083

۲. کارشناسی ارشد، گروه مدیریت مالی، دانشگاه ارومیه، ارومیه، ایران. (ahejaziyan@yahoo.com).

۳. دانشیار، گروه حسابداری، دانشگاه ارومیه، ارومیه، ایران. (نویسنده مسئول). (g.mansourfar@urmia.ac.ir).

۴. استادیار، گروه حسابداری، دانشگاه ارومیه، ارومیه، ایران. (f.ghayour@urmia.ac.ir).


حق انتشار این مستند، متعلق به نویسندگان آن است. © ۱۴۰۳. ناشر این مقاله، سازمان بورس و اوراق بهادار است.

این مقاله تحت گواهی زیر منتشر شده و هر نوع استفاده غیرتجاری از آن مشروط بر استناد صحیح به مقاله

و با رعایت شرایط مندرج در آدرس زیر مجاز است.

Creative Commons Attribution-NonCommercial 4.0 International license

(https://creativecommons.org/licenses/by-nc/4.0/)



مقدمه

در عصر حاضر، بنگاه‌های تجاری در محیطی به شدت رقابتی و متغیر فعالیت می‌کنند. در این محیط رقابتی، آن دسته از شرکت‌هایی که نتوانند خود را برای فرآیند رشد و توسعه هم‌ردیف با شرکت‌های پیشرو هماهنگ کنند به تناوب از گردونه رقابت خارج می‌شوند. بحران مالی سال ۲۰۰۸ آسیب‌پذیری سیستم مالی را آشکار کرد. در این بحران، بنگاه‌های اقتصادی بیش از هر زمان دیگری با مشکلات مالی روبرو شدند، از این رو مسئله پیش‌بینی درماندگی مالی در شرکت‌ها به یک زمینه پژوهشی عمده در زمینه مالی تبدیل شده است (وگانزون‌ها^۱، ۲۰۱۸).

صاحبان سرمایه به دنبال روش‌هایی هستند تا بتوانند وضعیت مالی شرکت را قبل از اینکه به مرحله ورشکستگی برسد، پیش‌بینی کنند. مرحله قبل از ورشکستگی، در اصطلاح درماندگی مالی نامیده می‌شود. درماندگی مالی به شرایطی گفته می‌شود که شرکت نتواند به تعهدات خود در قبال تامین‌کنندگان منابع مالی عمل کند یا برای عمل به این تعهدات دچار مشکل شود که این شرایط در صورت ادامه می‌تواند منجر به ورشکستگی شود. ورشکستگی زمانی اتفاق می‌افتد که شرکت قادر به پرداخت بدهی‌های خود نباشد که در نهایت منجر به انحلال شرکت می‌شود (خلیق و همکاران^۲، ۲۰۱۴). درماندگی مالی را به عنوان مرحله میانی بین ورشکستگی و وضعیت سالم تعریف می‌کنند. از نظر مفهومی، درماندگی مالی و ورشکستگی، هر دو اوضاع وخیم مالی را نشان می‌دهند اما وضعیت حقوقی و قانونی آن‌ها متفاوت است. یک شرکت زمانی که به لحاظ قانونی به طور رسمی به عنوان ورشکسته شناخته شد، به ناچار مراحل تسویه را طی خواهد کرد. در حالی که یک شرکت درمانده هیچگاه توسط دادگاه ورشکسته اعلام نشده و ممکن است پس از بهبودی موفق شود به وضعیت سالم خود بازگردد. البته، هر چه وضعیت مالی نامساعد شود، بهبودی دشوارتر شده و کمتر احتمال دارد یک شرکت دوباره سالم شود (عمر فاروق و همکاران^۳، ۲۰۱۸). یکی از نتایج حل مشکل درماندگی مالی این است که یک شرکت می‌تواند به طور کارآمد از فرصت‌های سرمایه‌گذاری استفاده کرده و منابع خود را به صورت مناسب‌تری تخصیص دهد و نیز بین فرصت‌های مطلوب سرمایه‌گذاری و فرصت‌های نامطلوب سرمایه‌گذاری تمایز قائل شود (فلاح‌پور و همکاران، ۲۰۱۷). بنابراین، لازم است برای پیش‌بینی درماندگی مالی از مدل‌ها و ابزارهای مناسب استفاده شود.

1. Vaganzones

2. Khaligh & et al

3. Umar Farooq & et al

افزون بر انتخاب متغیرهای مناسب برای پیش‌بینی و همچنین انتخاب مدل مناسب برای پیش‌بینی با بالاترین دقت، ضروری است معیارهای درماندگی مالی نیز به طور مناسب انتخاب شود تا بهترین مدل برازش شده از مجموعه عوامل بتواند کلیه افراد و گروه‌های دینفع را در امر پیش‌بینی درماندگی مالی شرکت‌ها یاری کند. در این پژوهش سعی بر آن است با رویکردی جدید به مسئله پیش‌بینی درماندگی مالی پرداخته شود.

از تئوری مجموعه راف در پیش‌بینی شاخص‌های مالی و قیمت سهام استفاده‌های متعددی شده است. در این زمینه می‌توان به طور مثال به مطالعات مینگ تای وو و همکاران^۱ (۲۰۲۱)، یلدیریم و همکاران^۲ (۲۰۲۱)، پاتیل^۳ (۲۰۲۰)، دونگ روی چن و همکاران^۴ (۲۰۱۹) اشاره کرد. با این تئوری می‌توان رابطه بین اجزای مختلف سیستم و ارتباط بین آن‌ها را نشان داد. با این حال، باوجود استقبال از رویکرد نظریه مجموعه‌های راف در سایر زمینه‌های مالی، این تئوری برای پیش‌بینی درماندگی مالی با توجه به هزینه‌های درماندگی برای شرکت‌های درمانده که شامل: هزینه فرصت‌های از دست رفته شرکت از جمله فروش‌های از دست رفته شرکت، کاهش سودآوری و زیان از دست دادن موقعیت بازار که منجر به بدتر شدن وضعیت پرداخت بدهی‌ها می‌شود یا هزینه بالای تامین مالی و جذب سرمایه‌گذار جدید اشاره کرد. هزینه دیگر آن، هزینه روانی است که موجب می‌شود سرمایه‌گذاران با تردید به فرصت‌های سرمایه‌گذاری نگاه کنند از این رو، انجام اقدامات به موقع برای جلوگیری از بدتر شدن ساختار مالی و کاهش ریسک عدم قدرت پرداخت دیون در مراحل اولیه ناتوانی امری اجتناب ناپذیر است. مورد استفاده قرار گیرد. با توجه به دقت بالای تئوری راف در سایر موارد پیش‌بینی و دقت بالای شبکه‌های عصبی مصنوعی در پیش‌بینی‌های صورت گرفته، این مطالعه به دنبال پیش‌بینی درماندگی مالی بر اساس روش‌های نوین ریاضیات ماتریسی است که استوار بر کاربرد و کارایی تئوری مجموعه راف است. برای تشخیص شرکت‌های درمانده مالی از غیردرمانده نیز از معیار آسکویت و همکاران^۵ (۱۹۹۴) به عنوان یکی از معتبرترین روش‌ها برای شناسایی شرکت‌های درمانده مالی از غیردرمانده (علی اکبرلو و همکاران، ۱۳۹۹) استفاده شده است.

1. Wu, Jimmy Ming-Tai, et al

2. Yildirim & et al.

3. patil

4. Dong-Rui Chen & et al.

5. Asquith & et al

همچنین به منظور بررسی کارایی تئوری مجموعه راف در پیش‌بینی درماندگی مالی، نتایج حاصل با شبکه‌های عصبی مصنوعی پر کاربرد که عبارتند از: شبکه عصبی چندلایه پرسپترون^۱ (MLP) و شبکه توابع شعاع پایه^۲ (RBF) و سیستم استنتاج فازی تطبیق‌پذیر^۳ (ANFIS) مقایسه شده است.

مبانی نظری و توسعه فرضیه‌ها

از نظر سان و همکاران^۴ (۲۰۲۰) درماندگی مالی به این معناست که بنگاه اقتصادی با تهدیدی از فضای اقتصادی خارجی یا شکست تصمیم‌گیری داخلی روبرو شده و به دلیل ناکافی بودن جریان پولی دچار مشکل می‌شود یا حتی ممکن است به نتایج بدتری از جمله ورشکستگی، در ادامه دچار شود. به عبارتی، درماندگی مالی به کاهش شرایط ثبات مالی قبل از اعلام ورشکستگی یا انحلال شرکت گفته می‌شود.

تئوری مجموعه راف توسط پژوهشگر لهستانی به نام پاولاک^۵ در سال ۱۹۸۲ معرفی شد. از آنجا که پژوهش‌های اولیه در این زمینه به زبان لهستانی منتشر شد، بنابراین نظر پژوهشگران علوم کامپیوتر و ریاضیات در سطح بین‌المللی را جلب نکرد و توجه چندانی به این تئوری صورت نگرفت. در اواخر دهه ۸۰ این تئوری در سطح جهانی مطرح شد و در سال ۱۹۹۲ نخستین کنفرانس علمی تئوری مجموعه راف به صورت بین‌المللی در لهستان برگزار شد. در سال ۱۹۹۵ از سوی ACM به عنوان موضوع نوظهور در علم کامپیوتر معرفی شد و در سال ۱۹۹۸ مجله علم اطلاعات مجموعه‌ای از مقالات مربوط به مجموعه‌های راف را چاپ کرد. کاربرد مجموعه‌های راف را می‌توان به تحلیل‌های تصمیم‌گیری و غیرتصمیم‌گیری تقسیم کرد. تحلیل‌های غیرتصمیم‌گیری به طور عمده فشرده کردن اطلاعات، تقلیل اطلاعات، خوشه‌بندی، کشف الگو و همانند آن را شامل می‌شود. در واقع کارکرد اصلی این دسته از تحلیل‌ها آن است که ویژگی‌های غیرضروری را حذف کرده و با فشرده کردن و تقلیل داده‌ها، امکان تحلیل بهتر داده‌ها را فراهم کنند. تحلیل‌های تصمیم‌گیری نیز به کشف و استخراج قوانین تصمیم کمک می‌کنند. هرچند اساس این تئوری علوم کامپیوتر و ریاضیات است، اما در سایر علوم نظیر پزشکی، علوم اجتماعی و علم اقتصاد به روش‌های مختلفی از آن استفاده شده است (کریمی و صادقی، ۱۳۹۴).

1. Multi-layer perceptron
2. Radial basis function
3. Adaptive-network-based fuzzy inference system
4. Sun & et al.
5. Pawlak

مفاهیم تئوری مجموعه‌های راف بر این فرض متکی است که هر عضو مجموعه مورد بحث با برخی اطلاعات مرتبط است. به عنوان مثال، اگر اعضا، دارایی‌های موجود در یک بازار باشند، اطلاعات مربوط به دارایی‌ها شامل رفتار قیمت و ویژگی‌های اقتصادی است. اعضای که با اطلاعات مشابه مشخص می‌شوند، از منظر اطلاعات مستتر در آنها، غیرقابل تمایز (شبه) است. رابطه عدم تمایز، از این نظر، مبنای ریاضی در تئوری مجموعه‌های راف شده است. مهم‌ترین مسائلی را که می‌توان با استفاده از تئوری مجموعه راف حل کرد عبارت‌اند از: تفسیر مجموعه‌ای از اعضا از نظر مقادیر مشخصه‌ها، کنترل وابستگی بین ویژگی‌ها (کامل یا جزئی)، کاهش مشخصه‌ها، تجزیه و تحلیل اهمیت ویژگی‌ها و تولید قوانین تصمیم‌گیری (پاولاک، ۱۹۹۷). تئوری راف خواص توپولوژیکی یک گراف را که به عنوان مدلی که روابط زوجی بین اشیاء را نشان می‌دهد، بررسی می‌کند. سودمندی تئوری راف در این است که بسیاری از انواع روابط و فرآیندها در علم و فناوری را می‌توان با نمودارها مدل کرد و فرمالیسم یکپارچه نمودارها، حل بسیاری از مسائل با بررسی خواص توپولوژیکی نمودارها را ممکن می‌سازد.

تکنیک‌های آماری مختلفی برای پیش‌بینی ورشکستگی از جمله تحلیل تک متغیره، مدل لاجیت، مدل پروبیت و شبکه‌های عصبی استفاده شده است. در سال ۲۰۲۱ چو و گاراس^۱ به بررسی پیش‌بینی ورشکستگی با استفاده از تئوری راف پرداختند. در این پژوهش با استفاده از یافته‌های تجربی روش پیشنهادی برای پیش‌بینی ورشکستگی با استفاده از مجموعه‌های راف اعتبارسنجی شد. روش پیشنهادی یک رویکرد جدید برای ارزیابی توانایی مالی یک شرکت را ارائه می‌دهد. در این پژوهش با استفاده از منابع موجود، پنج نسبت مالی که شاخص‌های خوبی از توان پرداخت بدهی مالی است، در نظر گرفته شده است. تعاملات بین این پنج شاخص می‌تواند به عنوان شاخصی از توان مالی یک شرکت در نظر گرفته شده است. این پژوهش ارزش مدل پیشنهادی را در ارزیابی توان پرداخت بدهی مالی یک شرکت و احتمال ورشکستگی یک شرکت در آینده نزدیک اثبات می‌کند.

با افزایش بی‌سابقه داده‌ها در سراسر جهان، بخش‌های مالی مانند شرکت‌ها و صنایع سعی می‌کنند، خود را به سازمان‌های داده‌محور تبدیل کنند. تجزیه و تحلیل داده‌های بزرگ^۲ (BDA) با ارائه پردازش غیرمتمرکز و توزیع شده بر این مشکلات غلبه می‌کند. ییلدروم و

1. Choe & Garas

2. Big data analysis

همکاران در پژوهشی در سال ۲۰۲۱ سعی کردند با استفاده از تئوری مجموعه راف داده‌های بزرگ را تجزیه و تحلیل کنند. در این پژوهش با استفاده از دو مدل DPMoel-1 (روش رگرسیون لجستیک^۱ و یادگیری ماشین^۲) و DPMoel-2 (روش راف) داده‌های پیش فرض مورد تجزیه و تحلیل قرار گرفته که نتایج حاصل نشان از موفقیت بیشتر DPMoel-2 در تجزیه و تحلیل داده‌ها دارد.

در سال ۲۰۱۹ جوزف آتیا^۳ به بررسی کارآرایی تئوری راف در بازار سهام پرداخت. او با استفاده از نرم افزار پایتون ماتریسی بر اساس همبستگی بین قیمت سهام، نموداری رسم کرد که بر اساس تحلیل آن می‌توان به همبستگی رفتار سهام در دوره‌های سوددهی پرداخت.

استفاده از مدل‌سازی ریاضی و شبکه‌های عصبی مصنوعی (ANN)^۴ نیز تا حد زیادی در زمینه اقتصاد افزایش یافته‌است. این تکامل نه تنها منجر به توسعه بسیاری از کاربردهای علمی مختلف شده بلکه به کاوش فشرده در موضوعات عملی منجر شده است. مغز انسان یکی از پیچیده‌ترین شبکه‌های جهان است و مطالعات بر روی خواص استاتیکی و دینامیکی آن در سال‌های اخیر رشد انفجاری داشته است. پیشرفت‌ها در نظریه مجموعه راف و علوم شبکه اعصاب (یعنی مطالعه ساختار یا عملکرد سیستم عصبی) فرصتی را برای درک جزئیات این پدیده پیچیده و مدل‌سازی آن ارائه می‌دهد. تئوری راف تئوری گرافیکی از شاخه‌های ریاضیاتی است که هر شیء از منظر ریاضی شامل یک سری نقاط و اتصالات میان آنهاست که این نقاط گراف‌ها نامیده می‌شود. گراف‌ها در طیف وسیعی از مسائل کاربرد دارند. تئوری مجموعه‌های راف از ابزارهای مناسب برای کشف دانش در پایگاه‌های داده یا به عبارت دیگر یکی ابزارهای ریاضی برای کشف الگوهای مستتر در داده‌ها است و به مرور زمان کاربردهای متنوعی مانند: محاسبات نرم، یادگیری ماشینی، تصمیم‌گیری، داده کاوی و ... پیدا کرد. همچنین ویژگی‌های شبکه‌های عصبی مصنوعی مانند بهره‌وری، استحکام و انطباق، آن‌ها را به ابزاری ارزشمند برای طبقه‌بندی، پشتیبانی و تصمیم‌گیری، تحلیل مالی یا امتیازدهی تبدیل کرده‌است (تاکاک و ورنر^۵، ۲۰۱۶). یادگیری ماشین، تلاقی بین آمار و علوم کامپیوتر و متعلق به حوزه هوش مصنوعی، به دلیل دسترسی بهتر به داده‌های بزرگ و محاسبات کم هزینه، در حال بهبود

1. Logistic Regression
2. Machine Learning
3. Joseph Attia
4. Artificial Neural Networks
5. Tkác & Verner

مداوم است. ساختارهای شبکه، با ظرفیت نگاشت قوی خود، قادر به مدیریت تعاملات بین متغیرها و ارتباطات غیرخطی هستند (سید مارسو و ایل مروانی^۱، ۲۰۲۰). بیشتر پژوهش‌ها، به دنبال یافتن یک مدل مناسب برای پیش‌بینی درماندگی مالی هستند که با کمترین سطح خطای ممکن همراه باشد، به همین منظور در سال‌های اخیر ساختارهای ریاضیات و تکنیک‌های هوش مصنوعی و داده‌کاوی مثل شبکه عصبی مصنوعی (ANN)، (گرگوا و همکاران^۲، ۲۰۲۰) و مدل ماشین بردار پشتیبان (SVM)^۳ (منصورفر و همکاران، ۱۳۹۴)، (مرادی و همکاران، ۱۳۹۱) و مدل الگوریتم ژنتیک^۴ (گرگی‌زاده و همکاران، ۱۳۹۳)، رگرسیون لجستیک لاسو^۵ (نماری و ابراهیمی، ۱۳۹۸) و.... مورد استفاده قرار گرفته‌است. تجربه نشان داده است با پیشرفت علم داده‌کاوی، الگوریتم‌های جدید از جمله شبکه عصبی مصنوعی (ANN) و شبکه‌های عصبی فازی تطبیق پذیر (ANFIS) از توانایی بالایی برای پیش‌بینی برخوردار هستند (بحیرانی و همکاران، ۱۳۹۵).

عالمیه و همکاران^۶ (۲۰۲۱) از روش تکثیر شبکه عصبی مصنوعی (ANN) استفاده کرده‌اند و مدل ANN را به دسته‌های زمانی که شامل t-2، t-3 و t-4 است تقسیم کرده‌اند. نتایج ایشان نشان می‌دهد که شبکه عصبی مصنوعی در گروه t-4 با دقت ۹۵/۶٪ برای درماندگی مالی از دقت بیشتری برخوردار است. گرگوا و همکاران (۲۰۲۰) با استفاده از سه روش مختلف (رگرسیون لجستیک، جنگل تصادفی^۷ و مدل‌های شبکه عصبی مصنوعی) به منظور شناسایی یک مدل با بالاترین دقت پیش‌بینی کنندگی درماندگی مالی در شرکت‌های صنعتی اسلوآکی نشان دادند که مدل‌های شبکه عصبی عملکرد بهتری را با تمام ویژگی‌های عملکردی اندازه‌گیری می‌کنند و همچنین نتایج ما بر اهمیت مدل شبکه عصبی برای پیش‌بینی درماندگی تأکید کرده و ارتباط آن را برای ارزیابی درماندگی مالی بنگاه‌های صنعتی برجسته می‌کند.

در سال ۱۳۹۶ سارنج و همکاران از تئوری مجموعه راف برای پیش‌بینی قیمت سهام استفاده کردند. در این پژوهش روشی مبتنی بر تئوری مجموعه‌های راف و با استفاده از شاخص‌های تحلیل تکنیکی به منظور پیش‌بینی قیمت سهام ارائه شده است.

1. Said Marso & el Merouani
2. Gregova & et al
3. Support Vector Machines
4. Genetic algorithm
5. Lasso Logistic Regression
6. Alamsyah & et al
7. Random Forest

وقفی (۱۳۹۸) با استفاده از استفاده از الگوریتم‌های هوش مصنوعی، ماشین بردار پشتیبان کرنل گوسی و الگوریتم قانون‌گرا چاید به بررسی کاربرد الگوریتم‌های هوش مصنوعی در پیش‌بینی ورشکستگی مالی پرداخت. نتایج پژوهش وی نشان می‌دهد الگوریتم‌های قانون‌گرا و ماشین‌بردار دارای قدرت بالایی در پیش‌بینی ورشکستگی مالی است.

در پژوهشی دیگر مهربان‌پور و همکاران (۱۴۰۱) با ترکیب روش‌های تحلیل مولفه‌های اصلی و مجموعه‌های راف، مدلی به منظور پیش‌بینی قیمت سهام ارائه دادند. بدین منظور از داده‌های قیمتی شرکت ایران خودرو استفاده شد. نتایج به‌دست آمده از مدل ترکیبی با نتایج حاصل از مدل مجموعه‌های راف مقایسه شد. با بررسی ضرایب متغیرهای اولیه در عامل‌های جدید این موضوع مهم قابل نتیجه‌گیری است که با حفظ بخش عمده خواص داده‌های اولیه، پنج متغیر اولیه قابل کاهش به دو عامل بوده که این موضوع نقش مهمی در کاهش تعداد قواعد تصمیم و ملموس بودن استفاده از آن‌ها دارد. در این پژوهش درصد پیش‌بینی‌های صحیح قواعد استخراج شده از مدل ترکیبی نسبت به مدل رقیب یعنی مدل مجموعه‌های راف، بیشتر و تعداد قواعد کمتر است.

پژوهش حاضر به دنبال بررسی توانایی پیش‌بینی تئوری مجموعه راف برای پیش‌بینی درماندگی مالی شرکت‌های فعال در بورس اوراق بهادار تهران براساس معیار آسکویت و همکاران (۱۹۹۴) است. معیار آسکویت و همکاران (۱۹۹۴)، در مقایسه با سایر روش‌های شناسایی شرکت‌های درمانده مالی در شرایط حاکم بر شرکت‌های ایرانی مستقر در بورس اوراق بهادار تهران، مانند آلتمن (۱۹۹۵)، ماده ۱۴۱ قانون تجارت ایران و آلتمن (۱۹۶۸) تفکیک بهتری ارائه می‌دهد (علی‌اکبرلو و همکاران، ۱۳۹۹). افزون بر این برای بررسی دقیق‌تر و کارایی پیش‌بینی صورت گرفته توسط مجموعه راف، نتایج حاصل با الگوریتم شبکه‌های عصبی مصنوعی و فازی منتخب که عبارتند از: شبکه عصبی چندلایه پرسپترون (MLP) و شبکه توابع شعاع پایه (RBF) و سیستم استنتاج فازی تطبیق‌پذیر (ANFIS) مورد مقایسه و بررسی مجدد قرار گرفت.

روش‌شناسی پژوهش

جامعه آماری پژوهش حاضر شامل، کلیه شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران است. بخش عمده‌ای از اطلاعات مربوط به صورت‌های مالی از نرم‌افزار ره‌آورد نوین و سایت اینترنتی بورس اوراق بهادار تهران استخراج شده‌است. برای پیش‌بینی درماندگی مالی شرکت‌های فعال در بورس اوراق بهادار تهران که در بازه زمانی ۱۳۸۵-۱۳۹۹ فعالیت داشته‌اند

و برای انتخاب نمونه‌های مورد آزمایش از روش حذف سیستماتیک استفاده شده است. نمونه پژوهش، متشکل از دو گروه شرکت‌های درمانده براساس معیار اسکویت و همکاران (۱۹۹۴) و شرکت‌های سالم هستند. به منظور رعایت همگنی، تلاش شده است که شرکت‌های سالم و درمانده حتی الامکان از یک صنعت و به لحاظ اندازه، ارزش بازار یکسانی داشته باشند. همچنین محدودیت‌هایی که برای انتخاب شرکت‌های نهایی در نظر گرفته شده‌اند به قرار زیر هستند:

- اطلاعات مورد نیاز شرکت‌ها در طول دوره پژوهش در دسترس باشد.
- سال مالی شرکت به ۲۹ اسفند ماه ختم شود.
- جزو شرکت‌های واسطه‌گری مالی مانند سرمایه‌گذاری‌ها و بانک‌ها و غیره نباشد.
- در دوره زمانی مورد بررسی تغییر سال مالی نداشته باشد.
- قبل از سال ۱۳۸۴ در بورس اوراق بهادار تهران پذیرفته شده باشند.
- صورت‌های مالی و یادداشت‌های همراه شرکت‌ها در سال‌های مالی ۱۳۸۵ تا ۱۳۹۹ را در دوره مورد مطالعه ارائه داده باشند.
- تمامی اطلاعات مربوط قابل دستیابی باشند.

پس از جمع‌آوری داده‌های آماری، از نرم‌افزار Excel به منظور جمع‌بندی و محاسبات مورد نیاز بهره گرفته شده است و نتایج حاصل از آن در نرم‌افزارهای آماری ROSETTA برای ترسیم مجموعه‌های راف و از نرم‌افزار MATLAB به منظور ترسیم شبکه عصبی مصنوعی و فازی استفاده شده است. در انتها نتایج نهایی به دست آمده مورد تجزیه و تحلیل قرار می‌گیرد. شبکه‌های مورد استفاده در پژوهش شامل: شبکه عصبی چندلایه پرسپترون (MLP)، شبکه عصبی توابع شعاعی پایه (RBF) و شبکه سیستم‌های استنتاج فازی تطبیق‌پذیر (ANFIS) هستند که با استفاده از داده‌های ترکیبی مورد آزمایش قرار می‌گیرند. در گام آخر اقدام به مقایسه دقت پیش‌بینی‌های انجام گرفته، از طریق مربع مجذور میانگین خطا (RMSE)، میانگین قدرمطلق خطا (MAE)، درصد میانگین قدر مطلق خطا (MAPE%) شده است تا بر این اساس بهترین معیار و مدل برای پیش‌بینی درماندگی مالی را مشخص کنیم. بهترین شبکه، شبکه‌ای است که کمترین مقدار MAE، RMSE و MAPE% را دارد.

مرحله اول: تعیین متغیرهای پژوهش

در پژوهش حاضر به تبعیت از پژوهش مهرانی و همکاران (۲۰۱۷)، از ۲۷ شاخص (شاخص) نسبت مالی منتخب بهره گرفته شده است که به چهار گروه شاخص‌های سودآوری (اندازه‌گیری

ظرفیت کسب سود شرکت)، شاخص ایفای تعهدات (اندازه‌گیری برای توانایی ایفای تعهدات بلندمدت)، شاخص‌های فعالیت (اندازه‌گیری توانایی استفاده موثر از دارایی‌ها) و شاخص‌های جریان‌ات نقدی (اندازه‌گیری توانایی ایفای تعهدات کوتاه مدت) تقسیم شده‌اند. در جدول زیر شاخص‌های مالی و چگونگی محاسبه آن‌ها بیان شده است.

جدول ۱. شاخص‌های مالی پژوهش

گروه	نام متغیر	نحوه اندازه‌گیری
۱- شاخص‌های سودآوری	بازده خالص دارایی‌ها	متوسط کل دارایی‌ها / سود خالص
	بازده ناخالص دارایی‌ها	متوسط کل دارایی‌ها / سود قبل از بهره و مالیات
	بازده حقوق صاحبان سهام	متوسط حقوق صاحبان سهام / سود خالص
	نسبت حاشیه سود خالص	کل درآمد عملیاتی / سود خالص
	نسبت حاشیه سود ناخالص	کل درآمد عملیاتی / سود ناخالص
	نسبت سود عملیاتی به فروش	فروش / سود عملیاتی
	نسبت سود عملیاتی به متوسط حقوق صاحبان سهام	متوسط حقوق صاحبان سهام / سود عملیاتی
	نسبت سود عملیاتی به متوسط دارایی‌ها	متوسط دارایی‌ها / سود عملیاتی
	سود هر سهم	میانگین موزون سهام / سود خالص
	نسبت جاری	بدهی‌های جاری / دارایی‌های جاری
۲- شاخص‌های ایفای تعهدات	نسبت آتی	بدهی‌های جاری / دارایی‌های آتی
	نسبت سرمایه در گردش به دارایی‌ها	جمع دارایی‌ها / سرمایه در گردش
	نسبت سرمایه در گردش به فروش	فروش / سرمایه در گردش
	نسبت پوشش بهره	هزینه بهره / سود قبل از بهره و مالیات
	نسبت پوشش بدهی به حقوق صاحبان سهام	جمع حقوق صاحبان سهام / جمع بدهی‌ها
	نسبت بدهی	جمع دارایی‌ها / جمع بدهی‌ها
	گردش دارایی‌ها	متوسط دارایی‌ها / فروش
	گردش موجودی کالا	متوسط موجودی کالا / بهای تمام شده کالای فروش رفته
۳- شاخص‌های فعالیت	گردش حساب‌های دریافتی	متوسط حساب‌های دریافتی / فروش
	نسبت هزینه متوسط بدهی	متوسط بدهی‌ها / هزینه مالی
	گردش دارایی‌های ثابت	متوسط دارایی‌های ثابت / فروش
	نسبت گردش وجوه نقد عملیاتی	بدهی‌های جاری / جریان نقد عملیاتی
۴- شاخص‌های جریان‌ات نقدی	نسبت کیفیت سود	سود عملیاتی / وجه نقد حاصل از عملیات

گروه	نام متغیر	نحوه اندازه گیری
	نسبت بازده نقدی دارایی‌ها	متوسط دارایی‌ها / جریان نقد عملیاتی
	جریان نقد عملیاتی هر سهم	میانگین موزون سهام / جریان نقد عملیاتی
	میزان رشد جریان نقدی هر سهم	جریان نقد عملیاتی هر سهم دوره قبل / جریان نقد عملیاتی هر سهم دوره جاری

مرحله دوم: تعیین معیارهای شناسایی شرکت‌های درمانده

در این پژوهش از معیار آسکویت و همکاران (۱۹۹۴) به منظور تشخیص شرکت‌های درمانده از غیردرمانده استفاده شده است. بر اساس معیار آسکویت و همکاران (۱۹۹۴) شرکتی به عنوان درمانده مالی انتخاب می‌شود که در دو سال متوالی سود قبل از بهره، مالیات و استهلاک دارایی‌های مشهود و نامشهود شرکت کمتر از هزینه بهره گزارش شده و یا در هر سال سود قبل از بهره، مالیات و استهلاک شرکت کمتر از ۸۰ درصد هزینه بهره باشد.

مرحله سوم: مدل سازی

متغیر مستقل: در پژوهش حاضر از ۲۷ نسبت مالی استفاده شده است.
متغیر وابسته: درماندگی مالی به عنوان متغیر وابسته مورد آزمون و بررسی قرار گرفته است.
در اندازه‌گیری این متغیر به شرکت‌های درمانده عدد صفر و به شرکت‌های همتای سالم عدد یک تخصیص داده شده است.

مدل‌های استفاده شده

از آن‌جا که مجموعه‌های راف، اطلاعات اضافی در مورد داده‌ها را به طور پیش فرض نیاز ندارند، مزایای زیادی نسبت به استدلال آماری و احتمالاتی دارند. ورودی لازم به منظور تحلیل توسط مجموعه‌های راف به صورت جدول تصمیم است. یک جدول تصمیم ممکن است به دلیل وجود برخی مؤلفه‌ها زائد، بی دلیل بزرگ باشد. تعریف و استفاده از دو مفهوم اساسی هسته و بی زائده، موجب حذف مؤلفه‌های غیرضروری و حفظ بخش حیاتی و ضروری سیستم اطلاعات می‌شود. در جدول تصمیم، هر ردیف نمایش دهنده یک وضعیت، رخداد یا نمونه است و در هر ستون یک مشخصه یا مؤلفه از نمونه‌ها را نمایش می‌دهد. مجموعه‌های راف تقریبی از مفاهیم غیرقطعی از طریق دو مجموعه تقریب، بالا و پایین بوده و قادر است قضاوت

ذهنی و مبهم متخصصان را حتی در حالتی که اندازه مجموعه داده‌ها کوچک و یا توزیع آن مشخص نباشد، بررسی کند. تقریب پایین در برگیرنده اعضایی می‌باشد که قطعا عضو مجموعه مورد نظر هستند اما تقریب بالا در برگیرنده اعضایی است که «احتمالا» عضو مجموعه هستند.

تئوری مجموعه راف

تئوری مجموعه راف یک روش ریاضی برای دانش ناقص یعنی برای ابهام یا دقت پایین معرفی کرد. در این روش، ابهام توسط محدوده مرزی یک مجموعه بیان می‌شود. فرض شود U یک مجموعه متناهی از اعضاء بوده و یک رابطه زوجی $R \subseteq U \times U$ داده شده باشد. مجموعه‌های U و R به ترتیب مجموعه مرجع و رابطه عدم تمایز نامیده می‌شوند. رابطه عدم تمایز، فقدان دانش کافی در مورد عناصر U نمایش می‌دهد. برای سهولت، فرض می‌شود که R یک رابطه هم‌ارزی باشد. زوج (U, R) یک فضای تقریب نامیده می‌شود که U ، مجموعه مرجع و R یک رابطه هم‌ارزی در U است. فرض می‌شود X یک زیر مجموعه U باشد، یعنی $R \subseteq U$. هدف، توصیف مجموعه X بر اساس R می‌باشد. به منظور انجام این کار، به نشان‌گذاری بیشتر و مفاهیم پایه‌ای تئوری و مجموعه راف نیاز است که در زیر ارائه می‌شود. با استفاده از $R(x)$ ، کلاس هم‌ارز R نشان داده می‌شود، که توسط عضو x تعیین می‌شود. کلاس‌های هم‌ارز رابطه R که قطعات^۱ نامیده می‌شوند، بخش‌های مقدماتی دانش است که با توجه به R درک می‌شود. به طور کلی، تنها با استفاده از رابطه عدم تمایز قادر به مشاهده اعضای جداگانه U نیستند، بلکه تنها قطعات در دسترس دانش توسط این رابطه تشریح می‌شوند. مجموعه کلیه اعضایی که می‌تواند با اطمینان به عنوان اعضای X نسبت به R طبقه‌بندی شوند، تقریب پایین مجموعه X نسبت به R^* نامیده می‌شوند و با $R^*(X)$ نشان داده می‌شود، یعنی:

$$R^*(X) = \{x: R(x) \subseteq X\}$$

مجموعه کلیه اعضایی که تنها می‌توان به عنوان اعضای محتمل X نسبت به R طبقه‌بندی کرد، تقریب بالای R^* مجموعه X نسبت به R نامیده می‌شوند و با $R^*(X)$ نشان داده می‌شود، یعنی:

$$R^*(X) = \{x: R(x) \cap X \neq \emptyset\}$$

1. Granules

2. R-lower Approximation

3. R-upper Approximation


مجموعه کلیه اعضایی که نمی‌توان به‌طور قطع نه به عنوان عضو X و نه به عنوان عضو X نسبت به R طبقه کرد، محدوده مرزی^۱ مجموعه X نسبت به R نامیده می‌شود و با $RNR(X)$ نمایش داده می‌شود، یعنی:

$$RNR(X) = R^*(X) - R_*(X)$$

حال علائم و تعاریف مجموعه راف فرمول‌بندی می‌شود:

- یک مجموعه X قطعی^۲ است اگر و تنها اگر محدوده مرزی X تهی باشد.
- یک مجموعه X نسبت به R راف^۳ نامیده می‌شود اگر و تنها اگر محدوده مرزی X تهی نباشد.

تعاریف مربوط به تقریب پایین یک مجموعه شامل اجتماع کل قطعاتی است که به‌طور کامل در مجموعه قرار می‌گیرند، تقریب بالا، اجتماع کلیه قطعاتی است که تداخل غیر تهی^۴ با مجموعه دارند، محدوده مرزی یک مجموعه، تفاضل بین تقریب بالا و تقریب پایین مجموعه است. شکل (۱) تصویر گرافیکی تقریب‌های تعریف شده در بالا را نشان می‌دهد.



شکل ۱. تصویر مفهومی تقریب‌های مجموعه

1. Boundary Region
2. Crisp (exact)
3. Rough (Inexact)
4. Non-Empty Intersection

شبکه عصبی پرسپترون چند لایه (MLP)

شبکه‌های عصبی پرسپترون، به ویژه پرسپترون چند لایه، در زمره کاربردی‌ترین شبکه‌های عصبی هستند. این شبکه‌ها قادرند با انتخاب مناسب تعداد لایه‌ها و سلول‌های عصبی، که اغلب زیاد هم نیستند، یک نگاشت غیرخطی را با دقت دلخواه انجام دهند. شبکه عصبی پرسپترون چند لایه معمولاً از یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی تشکیل شده است. شبکه‌های عصبی مصنوعی جزء سیستم‌های داینامیکی هوشمند است.

در شبکه‌های عصبی پرسپترون، گره‌ها در لایه‌های متوالی قرار گرفته‌اند و ارتباط آن‌ها یک طرفه است زمانی که یک الگوی ورودی به شبکه وارد می‌شود، اولین لایه مقادیر خروجی‌اش را محاسبه کرده و در اختیار لایه بعد قرار می‌دهد. لایه بعد این مقادیر را به عنوان ورودی دریافت کرده و مقادیر خروجی‌اش آن به لایه بعد منتقل می‌شود. به همین ترتیب هر گره به گره‌های لایه بعدی سیگنال منتقل می‌کنند. تعداد لایه‌های پنهان و تعداد سلول‌های عصبی درون آن‌ها بر اساس روش آزمون و خطا تعیین می‌شود. مقادیر ورودی هر نورون در وزن متناظر آن‌ها ضرب می‌شود. سپس کل مقادیر ورودی وزنی با مقدار دیگری به نام «بایاس» جمع می‌شوند. مقدار بدست آمده از مرحله قبل به یک تابع غیر خطی معروف است که به عنوان یک تابع انتقال برای تولید مقدار خروجی نورون شناخته می‌شود.

شبکه‌های عصبی پرسپترون چند لایه می‌توانند با استفاده از مثال‌ها، خروجی دلخواه تولید کنند. فرایند یادگیری با مقایسه مقادیر خروجی مدل با مقادیر خروجی واقعی که به عنوان مقادیر هدف شناخته می‌شوند، اجرا می‌شود. دو نوع الگوریتم یادگیری وجود دارد: نظارت شده و بدون نظارت. الگوریتم انتشار با عملکرد آموزش Levenberg Marquardt یکی از محبوب‌ترین الگوریتم‌های یادگیری تحت نظارت است که کارایی خود را در پژوهش‌های مختلف ثابت کرده است. در این الگوریتم، مقادیر تصادفی قبل از شروع فرایند یادگیری به وزن‌ها اختصاص می‌یابد. در مرحله اول، مقادیر ورودی مدل از طریق عملکرد انتقال درون سلول‌های عصبی هر لایه به مقادیر خروجی مدل تبدیل می‌شوند. سپس اختلاف بین مقادیر خروجی به دست آمده و مقادیر هدف، که سیگنال خطا نامیده می‌شود، محاسبه می‌شود. سیگنال‌های خطا سپس به سلول‌های عصبی شبکه منتقل می‌شوند تا مقادیر جدید وزن و بایاس را تعیین کنند. این روند ادامه خواهد یافت تا جایی که خروجی‌های مدل تا حد ممکن به مقادیر مورد نظر نزدیک شوند. بیشترین کاربردهای انتقال برای تکثیر برگشت به شرح زیر است:

عملکرد انتقال PURELIN که یک تابع خطی است به این صورت محاسبه می شود:

$$a = \text{purelin}(n) = n \quad \text{معادله (۱)}$$

$$\sum_{i=1}^N W_{ip} + b_p = n \quad \text{معادله (۲)}$$

$$a = \text{tansig}(n) = \frac{z}{1 + \exp(n)} \quad \text{TANSIG عملکرد تابع انتقال:}$$

$$a = \text{logsig}(n) = \frac{1}{1 + \exp(-n)} \quad \text{LOGSIG عملکرد تابع انتقال:}$$

n تعداد ورودی است، X_i مقدار ورودی نورون i است. W_{ip} وزن نورون های i در لایه پنهان p است. b_p مقدار بایاس لایه پنهان p است.

شبکه عصبی مصنوعی عملکرد پایه شعاعی (RBF)

شبکه عصبی مصنوعی عملکرد پایه شعاعی نوع دیگری از شبکه عصبی مصنوعی (ANN) است که الگوریتم آموزش سریع تری نسبت به شبکه های عصبی مصنوعی پرسپترون چند لایه دارد. تابع عملکرد شبکه عصبی مصنوعی پایه شعاعی از سه لایه تشکیل شده است: لایه ورودی، که داده های ورودی را در خود نگه می دارد. لایه مخفی که هسته های شبکه در آن قرار دارند. یک لایه خروجی، که مقدار خروجی شبکه را محاسبه می کند.

داده های لایه ورودی بدون هیچ گونه تغییر خاصی به هسته های لایه پنهان منتقل می شود. داده های دریافتی در هسته ها از طریق تابع انتقال درون هر هسته منتقل می شوند. بنابراین، خروجی هسته ها محاسبه می شود. سپس خروجی هر هسته در وزن مربوطه آن ضرب می شود. مقدار خروجی شبکه با جمع همه مقادیر وزنی حاصل از مرحله قبل به علاوه مقدار دیگری که به عنوان «بایاس» شناخته می شود، محاسبه می شود. محاسبات در هسته و لایه خروجی در زیر نشان داده شده است.

$$\varphi_m(X) \times \hat{y}_m = W_m \quad \text{معادله (۵)}$$

$$y = \sum_{i=1}^m w_m \times \varphi_m(x) + B \quad \text{معادله (۶)}$$

$\hat{y}_m$ خروجی هسته می باشد. X مقادیر ورودی متغیرها است. W_m وزن هسته هست. φ_m تابع انتقال در هسته است. y خروجی شبکه و B مربوط به وزن بایاس است.

در مطالعه حاضر، تابع Gaussian به عنوان تابع انتقال برای هسته‌ها در نظر گرفته شده است.

$$\varphi_m(x) = \exp\left(-\frac{\|x - c_m\|^2}{\theta_m^2}\right) \quad \text{معادله (۷)}$$

جایی که c_m مرکز است و θ_m گسترش دهنده هسته می‌باشد. شبکه عصبی مصنوعی پایه شعاعی زمانی بهینه است که خروجی‌های شبکه تا حد ممکن به مقادیر واقعی خروجی نزدیک باشند که به عنوان مقادیر هدف شناخته می‌شوند. دقت شبکه عصبی مصنوعی پایه شعاعی به تعیین مقادیر مناسب برای مراکز، وزن‌ها، گسترش دهنده و تعداد هسته‌های لایه پنهان بستگی دارد. تعداد هسته و مقدار گسترش دهنده توسط روش آزمون و خطا مشخص می‌شود. مقادیر بهینه برای مراکز و وزن‌ها در طی مراحل آموزش محاسبه می‌شود.

شبکه سیستم‌های استنتاج فازی تطبیق پذیر (ANFIS)

شبکه سیستم‌های استنتاج فازی تطبیق پذیر (ANFIS) به عنوان یک سیستم عصبی-فازی اساساً از پنج لایه تشکیل شده است.

ساختار کلی شبکه سیستم‌های استنتاج فازی تطبیق پذیر مشابه شبکه عصبی پرسپترون چند لایه است. لایه اول به عنوان لایه ورودی، لایه دو و سه به عنوان لایه‌های پنهان عمل می‌کنند، و لایه چهار و پنج، به عنوان لایه خروجی عمل می‌کنند. هر لایه در سیستم‌های استنتاج فازی تطبیق پذیر عملکرد و وظیفه خاص خود را دارد. معماری سیستم‌های استنتاج فازی تطبیق پذیر به ترتیب از پنج لایه تشکیل شده است: به ترتیب لایه فازی‌سازی، لایه قاعده، لایه عادی‌سازی، لایه رفع فازی و لایه خروجی.

لایه اول مقادیر ورودی را می‌گیرد و توابع عضویت متعلق به آن‌ها را تعیین می‌کند. در طی این مرحله، ورودی‌های استاندارد (ورودی‌های واضح) به ورودی‌های فازی تبدیل می‌شوند. برای شبکه سیستم‌های استنتاج فازی تطبیق پذیر دو ورودی و یک خروجی در نظر بگیرید.

$$O_{1i} = \mu_{A_{1I}}(X_1) \quad i=1,2,3,\dots \quad \text{معادله (۸)}$$

$$O_{2i} = \mu_{A_{2I}}(X_2) \quad i=1,2,3,\dots \quad \text{معادله (۹)}$$

X_1 و X_2 مقادیر ورودی هستند. A_{1I} و A_{2I} مقادیر فازی مربوط به هر متغیر ورودی هستند.

O_{1i} و O_{2i} به ترتیب تابع عضویت مجموعه‌های فازی A_{1I} و A_{2I} هستند.

لایه دوم وظیفه تولید قدرت شلیک برای قوانینی را دارد که با معادله (۳) قابل محاسبه است.

$$w_i = \mu_{A_{1I}}(X_1) \mu_{A_{2I}}(X_2) \quad i = 1,2,3,\dots \quad \text{معادله (۱۰)}$$

نقش لایه سوم عادی سازی مقاومت شلیک محاسبه شده است.

برای محاسبه از سیستم استنتاج فازی پیشنهاد شده توسط (Takagi and Sugeno 1983)

استفاده می شود.

$$\hat{W}_i = \frac{w_i}{w_1 + w_2} \quad i=1,2 \quad \text{معادله (۱۱)}$$

لایه چهارم مقادیر نرمالیزه شده از مرحله قبل و همچنین مجموعه پارامترهای نتیجه را می گیرد.

$$\hat{W}_i f_{i=\hat{W}_i}(p_i x_1 + q_i x_2 + r_i) \quad i=1,2 \quad \text{معادله (۱۲)}$$

لایه پنجم مقدار خروجی نهایی همه قوانین را محاسبه می کند.

$$y = \sum_{i=1}^2 \hat{W}_i f_i = \frac{\sum_{i=1}^2 \hat{W}_i f_i}{\sum_{i=1}^2 w_i} \quad i=1,2 \quad \text{معادله (۱۳)}$$

در گام آخر پس از طراحی شبکه، ورود داده ها و رسیدن به ترکیب بهینه و انجام پیش بینی توسط آن، از معیارهای ارزیابی پیش بینی شبکه، جهت بررسی داده های واقعی دوره زمانی پیش بینی و نتایج پیش بینی شبکه به شرح زیر استفاده می شود:

مرحله چهارم مقایسه نتایج: این معیارها برای مقایسه نتایج با مقیاس مختلف کاربرد دارد. برای مسائل پیش بینی، از برخی معیارهای عملکرد برای نشان دادن چگونگی یادگیری ارتباط های داده ها استفاده می شود که بیشتر مربوط به خطای بین خروجی های پیش بینی شده و خروجی مطلوب واقعی است. در این پژوهش، از چند معیار استفاده شده است که سه مورد: میانگین قدرمطلق خطا (MAE) و مربع مجذور میانگین خطا (RMSE) و درصد میانگین قدرمطلق خطا (MAPE) هستند. بهترین شبکه، شبکه ای است که کمترین مقدار RMSE, MAE و MAPE(%) را دارد.

جدول ۲. معیارها برای مقایسه نتایج

$\sqrt{\frac{\sum_{p=1}^p (d_p - z_p)^2}{p}}$	مربع مجذور میانگین خطا (RMSE)
$\frac{\sum_{p=1}^p d_p - z_p }{p}$	میانگین قدرمطلق خطا (MAE)
$\frac{\sum_{p=1}^p \left \frac{d_p - z_p}{d_p} \right }{p} \times 100$	درصد میانگین قدرمطلق خطا (MAPE %)

که d_p مقدار هدف است. Z_p مقدار پیش‌بینی شده و p تعداد داده‌ها است. لازم به بیان است که مقدار هدف مشخص است و به آن مقدار مشاهده شده نیز می‌گویند. به طور کلی هر چه مقدار سری واقعی (d_p) به مقدار پیش‌بینی آن (Z_p) نزدیک‌تر باشد، بر صحت بیشتر مدل پیش‌بینی دلالت دارد. بنابراین کیفیت یک مدل با بررسی میزان خطای پیش‌بینی یا همان e_p ارزیابی می‌شود.

$$e_p = d_p - Z_p \quad \text{معادله (۱۴)}$$

یافته‌های پژوهش

گام اول: تعیین داده‌های پژوهش

با استفاده از روش تمام شماری، تعداد ۶۵۸ سال-شرکت طبق معیار آسکویت و همکاران (۱۹۹۴) به عنوان نمونه تحت بررسی قرار گرفت. نمونه انتخابی از بین شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران طی دوره زمانی ۱۳۸۵ الی ۱۳۹۹ می‌باشد. فرایند جمع‌آوری داده‌های مربوط به شرکت‌ها بدین صورت بود که ابتدا معیارهای عمومی انتخاب نمونه بر روی کل جامعه آماری اعمال شده، سپس تعیین تعداد شرکت‌های نمونه درمانده براساس معیار آسکویت و همکاران (۱۹۹۴) و در نهایت شرکت‌های درمانده مالی انتخاب شده شامل ۳۲۹ شرکت بوده، پس از تعیین شرکت‌های درمانده، تعداد ۳۲۹ شرکت همسان براساس صنایع و ارزش‌های بازار نزدیک به شرکت‌های درمانده، به عنوان شرکت‌های غیردرمانده، انتخاب می‌شود. در این مطالعه شرکت‌ها به دو قسمت کلی تقسیم‌بندی شده‌اند، به شرکت‌های درمانده مالی عدد صفر و به شرکت‌های غیردرمانده عدد یک اختصاص داده شد.

گام دوم: گسسته‌سازی داده‌ها

در این گام، گسسته‌سازی داده‌ها (تولید بازه‌های گسسته) با استفاده از تکنیک‌های مختلف انجام شده و سپس داده‌ها به دو گروه یادگیری و کنترل به منظور انجام مراحل بعدی تقسیم می‌شوند. اختصاص ۷۵ درصد داده‌ها برای گروه یادگیری و مقدار ۲۵ درصد برای گروه کنترل مناسب است. داده‌های گروه یادگیری برای ساخت مدل از طریق ایجاد استخراج قواعد مورد استفاده قرار می‌گیرند و داده‌های گروه کنترل برای آزمون اعتبار مدل به کار می‌روند.

قبل از شروع تحلیل، داده‌های پرت، ناسازگار و گم‌شده شناسایی و نرمال سازی داده‌ها به منظور پردازش داده‌ها انجام و در نهایت بانک اطلاعاتی آماده تحلیل می‌شود.

در صورتیکه در فایل داده‌ها در بعضی رکوردها ناسازگاری وجود داشته باشد می‌توان با در نظر گرفتن با متغیر وابسته اصلی در فیلدهای هر رکورد تصحیحاتی انجام داد که در این پروژه انجام شد. اگر برای فیلدی در یک سری از رکوردها مقداری درج نشده باشد، داده مفقوده در نظر گرفته می‌شود.

فیلد رکوردهایی که اطلاعات کافی نداشته‌اند، حذف شدند. از نمودار باکس پلات به عنوان روش‌های تلخیص توصیفی استفاده شد تا تصویر جامعی از داده‌ها بدست آید و داده‌های پرت شناسایی شوند. اگر داده‌های پرت جز داده‌های اهمیت دار صورت مساله نباشند می‌توان با نظرخواهی از خبرگان در همان صنعت حذف کرد. با نرمال سازی، مقیاس داده‌ها به گونه‌ای تغییر کرد که آنها به دامنه کوچک و معین [۰, ۱] نگاشت شوند. نرمال سازی به این جهت انجام شده است که وقتی داده‌ها برای اندازه گیری فاصله به کار می‌روند، داده‌های با مقیاس بزرگ، نتیجه را به سمت خود منحرف نکنند. به این منظور، روش نرمال سازی Min-Max به کار گرفته شده است. این روش یک تبدیل خطی بر روی داده‌های اصلی انجام می‌دهد، به همین جهت است که در این روش رابطه بین مقادیر داده‌های اصلی حفظ می‌شود. فرض کنید که $\min_A$ و $\max_A$ به ترتیب حداقل و حداکثر مقادیر یک ویژگی باشند. یک نرمال سازی Min-Max یک مقدار V از A را به مقدار V' در فاصله $[\text{new min}_A, \text{new max}_A]$ نگاشت می‌کند که:

$$V' = \frac{V - \min_A}{\max_A - \min_A} (\text{new max}_A - \text{new min}_A) + \text{new min}_A$$

قبل از اینکه به سراغ مرحله تولید تقلیل‌ها در محاسبه هسته برویم به تعیین کلاس هم ارزی نیاز داریم. در نهایت برای تعیین مرز بین مشخصه‌ها در سیستم اطلاعاتی پیوسته، مقادیر متغیرهای پیوسته به صورت بازه‌ای با استفاده از الگوریتم آنتروپی به صورت گسسته در آمدند. برای تولید تقلیل‌ها از الگوریتم ژنتیک استفاده شد.

گام سوم: استخراج قوانین با استفاده از تئوری مجموعه راف است

بعد از مشخص کردن جدول تصمیم که حاوی داده‌های سری زمانی مربوط به مؤلفه‌های شرطی و مشخصه تصمیم است، جدول تصمیم به عنوان ورودی نرم افزار Rosetta تعریف

می‌شود. مراحل گسسته سازی، تولید بی‌زائده‌ها به روش‌های مختلف و استخراج قوانین توسط نرم‌افزار انجام می‌گیرد. مهمترین مرحله تولید قوانین مرتبط با تبیین مدل و به عبارت دیگر تبیین درماندگی مالی شرکت‌های پذیرفته شده در بازار سرمایه است که با محاسبه نرم‌افزار ۵۱۷۵۴ قانون تولید شد.

گام چهارم: بررسی قوانین استخراج شده و بررسی میزان دقت قوانین و تعداد داده‌هایی که هر کدام از قوانین را پشتیبانی می‌کنند در این مرحله انجام می‌گیرد.

گام پنجم: ارزیابی و مقایسه (اعتبارسنجی) قوانین حاصل از اعمال روش‌های مختلف با استفاده از ترکیب روش‌های مختلف گسسته سازی داده‌ها و تولید بی‌زائده‌ها، در مجموع، داده‌های گروه یادگیری مورد تجزیه و تحلیل قرار گرفتند و قوانین استخراج شده در هر حالت با استفاده از داده‌های گروه کنترل مورد آزمون قرار گرفته و شاخص دقت روش‌های مختلف باهم مقایسه شدند. هرچه شاخص دقت بالاتر باشد، قدرت پیش‌بینی قوانین حاصل از پردازش داده‌های یادگیری بالاتر است. برای اعتبارسنجی مدل از دو گروه داده به نام یادگیری و کنترل استفاده شد که در نهایت ۷۵ درصد داده‌ها در نمونه یادگیری و ۲۵ درصد داده‌ها در نمونه کنترل بودند. قوانین مدل مجدد بر روی داده‌های کنترل اجرا شد و در نهایت دقت مدل برابر ۹۸/۷ درصد به صورت زیر به دست آمد.

جدول ۳. نتایج اعتبارسنجی مدل

واقعی	پیش‌بینی شده			
		۰	۱	
	۰	۸۵	۰	۱/۰
	۱	۲	۷۷	۰/۹۷۴۶۸۴
		۰/۹۷۷۰۱۲	۱/۰	۰/۹۸۷۸۰۵
ROC	area	۳/۴۰۲۸۲۰		
	Std. error	۳/۴۰۲۸۲۰		
	Thr.(۰,۱)	۳/۴۰۲۸۲۰		
	Thr . acc	۳/۴۰۲۸۲۰		

گام ششم: مقایسه با سایر روش‌های پیش‌بینی

شبکه عصبی مصنوعی پرسپترون چند لایه شامل دو مرحله اصلی است: آموزش مدل، آزمایش مدل. مجموعه داده‌های جمع‌آوری شده (۶۵۸ داده) به سه گروه تقسیم می‌شوند: مجموعه داده‌های آموزشی ۸۵٪ داده‌ها (۵۵۹ داده)، مجموعه داده‌های اعتبارسنجی ۱۰٪ داده‌ها (۶۶ داده) و مجموعه داده‌های آزمون ۵٪ داده‌ها (۳۳ داده) است. مجموعه داده‌های آموزشی برای آموزش مدل استفاده می‌شود. مجموعه داده‌های اعتبارسنجی برای تعیین اینکه آیا مدل به اندازه کافی برای پیش‌بینی آموزش دیده است یا خیر استفاده می‌شود. داده‌های آزمون برای ارزیابی عملکرد مدل استفاده می‌شود. لازم به بیان است که داده‌های هر گروه از مجموعه‌ها در هر اجرا به صورت تصادفی انتخاب می‌شوند. عملکرد ANN-MLP به تعیین سه پارامتر بستگی دارد: تعداد لایه‌های پنهان، تعداد نوروها در هر لایه پنهان و نوع توابع انتقال. تعداد مختلفی از لایه‌های پنهان و نوروهای پنهان، و همچنین سه نوع تابع انتقال، برای توسعه مدل‌های ANN-MLP استفاده شد. بهترین شبکه، شبکه‌ای است که کمترین مقدار MAE، RMSE و MAPE(%) را دارد. در مدل‌های پیش‌بینی شده توسط MLP-ANN به ترتیب مدل‌ها با دو لایه پنهان و سه لایه پنهان و با چهار لایه پنهان پیش‌بینی شده‌اند. در این پژوهش از توابع انتقال TANSIG و LOGSIG برای لایه‌های پنهان استفاده می‌شود و لایه خروجی دارای تابع انتقال PURELIN است. در مطالعه حاضر این نوع مدل‌ها را «ML» نام‌گذاری می‌کنیم.

انواع ANNs- RFB برای بررسی مدل بهینه توسعه یافته‌اند. داده‌های جمع‌آوری شده به دو گروه تقسیم می‌شوند: مجموعه داده‌های آموزشی، مجموعه داده‌های آزمون. برای آموزش مدل از (۶۲۵ داده) و برای ارزیابی عملکرد مدل آموزش دیده از (۳۳ داده) استفاده می‌شود. لازم به بیان است که داده‌های هر گروه در هر اجرا به صورت تصادفی انتخاب می‌شوند. روند آموزش مدل RBF-ANN تا زمانی که عملکرد بهینه به دست آید ادامه می‌یابد. تابع گاوسی به عنوان تابع انتقال برای هسته‌ها در نظر گرفته شده است. در شبکه توابع شعاع پایه (RBF) سازه‌های مختلف براساس تعداد هسته‌ها بررسی می‌شود.

سیستم استنتاج فازی از الگوریتم یادگیری شبکه عصبی با استدلال فازی برای برآورد توزیع خروجی به کمک توزیع ورودی بهره می‌گیرد. سیستم عصبی-فازی از الگوریتم یادگیری (نظارت شده) برای بهینه‌سازی پارامترهای خطی و غیرخطی آموزش داده می‌شود. سیستم عصبی فازی نیز با پنج لایه (لایه ورودی، لایه توابع عضویت و ورودی، لایه قواعد، لایه برآیند، لایه

خروجی) است. برای توسعه مدل ANFIS از دو مجموعه داده استفاده شد. یکی برای آموزش مدل (۶۲۵ داده)، و دیگری برای ارزیابی عملکرد مدل (۳۳ داده). سه نوع تابع عضویت شامل تابع عضویت مثلثی (trimf)، تابع عضویت دوزنقه ای (trapmf) و تابع عضویت گاوسی (gaussmf) مورد استفاده قرار گرفت. نتایج بررسی‌ها در جدول زیر ارائه شده است.

جدول ۴. مقایسه جامع بین تمام مدل‌های توسعه یافته براساس معیار آسکویت و همکاران (۱۹۹۴)

مدل	نوع شبکه	تعداد نوروں و لایه / کرناں/نوع تابع عضویت	MAE	RMSE	MAPE(%)
ML ^۱	MLP	TANSIG,TANSIG {۸-۳}	۰/۰۶۲	۰/۱۷۷	۵/۶۷۱
ML ^۲	MLP	TANSIG,LOGSIG {۸-۲}	۰/۰۳۵	۰/۱۶۲	۳/۱۵۰
ML ^۳	MLP	TANSIG,TANSIG.TANSIG {۱-۵-۲}	۰/۱۱۹	۰/۱۳۷	۵/۶۰۹
ML ^۴	MLP	TANSIG,TANSIG,LOGSIG {۶-۹-۵}	۰/۱۳۰	۰/۳۶۰	۱/۰۲۵
۵	RBF	۵	۰/۱۱۳	۰/۳۳۵	۱۰/۱۳۸
۶	RBF	۱۰	۰/۰۵۵	۰/۲۳۴	۶/۷۱۴
۷	RBF	۱۲	۰/۰۹۰	۰/۲۳۴	۱۳/۷۲۰
۸	RBF	۱۶	۰/۱۰۳	۰/۳۲۱	۱۷/۲۴۳
۹	RBF	۲۰	۰/۰۹۷	۰/۳۱۲	۱۲/۵۴۰
۱۰	ANFIS	Trimf	۰/۱۸۹	۰/۲۸۹	۹/۷۱۹
۱۱	ANFIS	Trapmf	۰/۱۲۴	۰/۲۵۴	۳/۱۳۳
۱۲	ANFIS	Gaussmf	۰/۲۰۲	۰/۴۵۰	۱۳/۹۱۴

در مقایسه جامع بین مدل‌های ANN-MLP و ANN-RBF و ANFIS ارائه شده در جدول (۵) خطاهای محاسبه شده را برای هر گروه از مدل‌های توسعه یافته نشان می‌دهد.

جدول ۵. مقایسه جامع بین مدل‌های تئوری راف و شبکه عصبی مصنوعی

معیار		MAE	RMSE	MAPE
GRAPH THEORY		۰/۰۲۱	۰/۱۴۶	۱/۲۱۶
MLP-ANN		۰/۰۳۵	۰/۱۶۲	۳/۱۵۰
RBF-ANN		۰/۰۵۵	۰/۲۲۴	۶/۷۱۴
ANFIS		۰/۱۲۴	۰/۲۵۴	۳/۱۳۳

بحث و نتیجه‌گیری

پژوهش حاضر به دنبال یافتن روشی با ویژگی سهولت استفاده به منظور پیش‌بینی درماندگی مالی با دقت بالا، و مقایسه نتایج آن با شبکه‌های عصبی پرکاربرد بوده است. تئوری مجموعه‌های راف برخلاف احتمالات در آمار یا درجه عضویت در تئوری فازی تنها بر اساس داده‌های اصلی بوده و نیاز به هیچ گونه اطلاعات خارجی ندارد. این تئوری، حقایق مهم مستتر در داده‌ها را کشف و به زبان طبیعی قوانین تصمیم بیان می‌کند. خروجی نهایی تحلیل‌های انجام شده، یک سری قوانین ساده، قابل فهم و کاربردی است. مجموعه قوانین استخراج شده توسط مدل مجموعه راف، شرح کلی از دانش موجود در جدول‌ها و اطلاعات مالی موجود را ارائه می‌کند و داده‌های اضافی که حاوی اطلاعات خاصی نمی‌باشند را حذف می‌کند. قوانین به دست آمده از مدل مجموعه‌های راف مبتنی بر واقعیات است، زیرا هر قانون تصمیم توسط یک سری نمونه‌های واقعی پشتیبانی می‌شود. نتایج مدل راف، به راحتی قابل فهم است در حالی که نتایج حاصل از سایر روش‌های آماری، نیاز به تفسیر پارامترهای فنی دارد که ممکن است استفاده کننده با آن‌ها آشنا نباشد. در پژوهش حاضر تئوری مجموعه‌های راف با استفاده از ۷۵ درصد داده‌ها در نمونه یادگیری و ۲۵ درصد داده‌ها در نمونه کنترل و با اعمال مجدد قوانین بر روی داده‌های کنترل در نهایت دقت مدل برابر ۹۸/۷ درصد به دست آمد که از دقت و صحت بسیار بالایی برای پیش‌بینی درماندگی مالی براساس معیار آسکویت و همکاران (۱۹۹۴) برخوردار است. بررسی مقایسه‌ای نتایج حاصل از تئوری مجموعه راف با شبکه‌های عصبی مصنوعی منتخب برای شناسایی بهترین مدل برای پیش‌بینی درماندگی مالی طبق معیار آسکویت و همکاران (۱۹۹۴) نشان می‌دهد. تئوری مجموعه‌های راف با دارا بودن کمترین سطح خطا با اتکا به معیارهای MAPE, RMSE, MAE که به ترتیب عبارتند از: ۱/۲۱۶، ۰/۱۴۶، ۱/۲۱۶ دارای دقت و توانایی بیشتری نسبت به شبکه‌های مورد استفاده در پژوهش به منظور پیش‌بینی کنندگی درماندگی مالی را دارد. در مورد مقایسه شبکه‌ها با یکدیگر می‌توان بیان کرد که شبکه پرسپترون چند لایه (MLP) از دقت بیشتری نسبت به شبکه عصبی توابع شعاع پایه (RBF) و شبکه عصبی فازی استنتاج فازی تطبیق پذیر (ANFIS) برای پیش‌بینی درماندگی مالی برخوردار است. و همچنین شبکه توابع شعاع پایه (RBF) از دقت بیشتری نسبت به شبکه استنتاج فازی تطبیق پذیر (ANFIS) برخوردار است. به صورت دقیق‌تر می‌توان گفت شبکه پرسپترون چند لایه با تعداد دو لایه (TANSIG, LOGSIG) و به ترتیب دارای تعداد نورون‌های {۸-۲} بهترین

عملکرد را در بین مدل‌ها را ثبت کرد، در ادامه شبکه توابع شعاع پایه (RBF) با تعداد ۱۰ کرنال در رتبه بعدی و در شبکه عصبی-فازی تطبیق‌پذیر با تابع (TRIM membership function) دارای عملکرد بهتری نسبت به دو تابع فازی دیگر است. نتایج و ترتیب به دست آمده در پژوهش براساس معیار آسکویت و همکاران (۱۹۹۴) گواه این مدعاست که تئوری مجموعه راف از توانایی بالاتری به منظور پیش‌بینی درماندگی مالی در مقایسه با شبکه‌های استفاده شده در پژوهش برخوردار هست.

References

- Alamsyah, A; Kristanti, N; & Kristanti, F. T. (2021, March). Early warning model for financial distress using Artificial Neural Network. *In IOP Conference Series: Materials Science and Engineering* (Vol. 1098, No. 5, p. 052103).
- Ali Akbarlou, Alireza, Mansoorfar, Gholamreza, and Ghayor, Farzad. (2019). Comparing criteria for diagnosing financially distressed companies using logistic regression and artificial intelligence methods. *Financial Management Perspective*, 10(29), 147-166. doi: 10.52547/jfmp.10.29.147. (In Persian).
- Altman, D. G. (1995). Sustaining interventions in community systems: on the relationship between researchers and communities. *Health Psychology*, 14(6), 526.
- Altman, E. I. (1968). Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. *The journal of finance*, 23(4), 589-609.
- Comparing criteria for diagnosing financially distressed companies using logistic regression and artificial intelligence methods. *Financial Management Perspective*, 10(29), 147-166. (In Persian).
- Attia, J. (2019). The applications of graph theory to investing. arXiv preprint arXiv:1902.00786.
- Asquith, P; Gertner, R; & Scharfstein, D. (1994). Anatomy of financial distress: An examination of junk-bond issuers. *The Quarterly Journal of Economics*, 109(3), 625-658.
- Bahirai, Alireza, Etemidi, Kivan, & Grami Asal, Amir. (2015). Predicting financial bankruptcy of companies listed in Tehran Stock Exchange using ANN, ANFIS, LOGIT. *New Marketing Research Journal*, 153-166.(in Persian)
- Chen, D. R; Liu, C; Zhang, Y. C; & Zhang, Z. K. (2019). Predicting financial extremes based on weighted visual graph of major stock indices. *Complexity*, 2019.
- Choe, K; & Garas, S. (2021). The graph theoretical approach to bankruptcy prediction. *The Journal of Accounting and Management*, 11(1), 47-57.
- Khaliq, A; Altarturi, B. H. M; Thaker, H. M. T; Harun, M. Y; & Nahar, N. (2014). Identifying financial distress firms: a case study of Malaysia's governmentlinked companies.
- Fallahpour, S; Lakvan, E. N; & Zadeh, M. H. (2017). Using an ensemble classifier based on sequential floating forward selection for financial distress prediction problem. *Journal of Retailing and Consumer Services*, 34, 159-167.
- Farooq, U; & Qamar, M. A. J. (2019). Predicting multistage financial distress: Reflections on sampling, feature and model selection criteria. *Journal of Forecasting*, 38(7), 632-648.
- Gregova, E; Valaskova, K; Adamko, P; Tumpach, M; & Jaros, J. (2020). Predicting financial distress of slovak enterprises: Comparison of selected traditional and learning algorithms methods. *Sustainability*, 12(10), 3954.
- Gergizadeh, Majid, Jafaripour, Maitham, & Doshman Ziari, Hossein. (2013). Presentation of bankruptcy prediction model based on genetic algorithm in companies accepted in Tehran Stock Exchange. *Quarterly Journal of New Researches in Accounting*, 2(Number 4 (Summer 1993)), 81-92.
- Marso, S; & El Merouani, M. (2020). Predicting financial distress using hybrid feedforward neural network with cuckoo search algorithm. *Procedia Computer Science*, 170, 1134-1140. (In Persian).

- Mansourfar, G; Ghayour, F; Lotfi, B. (2015). The ability of support vector machine (SVM) in financial distress prediction. *Empirical Research in Accounting*, 5(1), 177-195. (In Persian).
- Mehrabanpour, Azar, Adel, & Shahramibabkan. (2022). Stock price forecasting by presenting a hybrid model using principal component analysis and rough set theory. *New Researches in Decision Making*, 26(7), 137-167. (In Persian).
- Mehrani, Dr. Sasan, Dr. Yahya, Dr. Sagheed, & Farzad Ghayur. (2016). the effect of the capital market cycle on the behavior of financial helplessness prediction models. *Journal of Accounting Knowledge*, 8(2), 35-62. (In Persian)
- Moradi, Mohsen, Shafiei Sardasht, Morteza, Ebrahimpour, Maleeha. (2011). Predicting financial distress of companies by support vector machine models and multiple audit analysis. *Stock Exchange Quarterly*, 5(18), 113-136. (In Persian).
- Namazi, Mohammad, Ebrahimi, Shahla. (2018). Predicting the financial distress of companies listed on the over-the-counter and Tehran Stock Exchanges using Lasso logistic regression. *Stock Exchange Quarterly*, 12(48), 5-38. doi: 10.22034/jse.2020.10991.1256. (In Persian).
- Pawlak, Z. (1982). Rough sets. *International journal of computer & information sciences*, 11(5), 341-356.
- Patil, P; Wu, C. S. M; Potika, K; & Orang, M. (2020, January). Stock market prediction using ensemble of graph theory, machine learning and deep learning models. In *Proceedings of the 3rd International Conference on Software Engineering and Information Management* (pp. 85-92).
- Tkáč, M; & Verner, R. (2016). Artificial neural networks in business: Two decades of research. *Applied Soft Computing*, 38, 788-804.
- Wu, J. M. T; Li, Z; Srivastava, G; Tasi, M. H; & Lin, J. C. W. (2021). A graph-based convolutional neural network stock price prediction with leading indicators. *Software: Practice and Experience*, 51(3), 628-644.
- Karimi, T. & Sadeghi moghadam, M. (2015). Rough sets and Grey sets, Ketab mehraban, Tehran. 1-159. (In Persian).
- Saranj, Alireza, Qods, Majid, & Tehrani, Reza. (2017). Forecasting the total index of Tehran Stock Exchange using the combined approach of meta-heuristic algorithms, artificial intelligence and wavelet parametric equation. *Financial Engineering and Securities Management*, 9(35), 365-391. (In Persian).
- Sun, J; Li, H; Fujita, H; Fu, B; & Ai, W. (2020). Class-imbalanced dynamic financial distress prediction based on Ad boost-SVM ensemble combined with SMOTE and time weighting. *Information Fusion*, 54, 128-144.
- Vaghfi, S. H. (2019). Using artificial intelligence algorithm in Financial Bankruptcy by Macro-economic and Accounting variables in listed companies for stock exchange in Tehran. *Journal of Decisions and Operations Research*, 4(2), 158-173. (In Persian).
- Veganzones, D; & Séverin, E. (2018). An investigation of bankruptcy prediction in imbalanced datasets. *Decision Support Systems*, 112, 111-124.
- Yıldırım, M; Okay, F. Y; & Özdemir, S. (2021). Big data analytics for default prediction using graph theory. *Expert Systems with Applications*, 176, 114840.